

Suvremena psihologija 12 (2009), 2, 283-296

Izvorni znanstveni članak - UDK 159.922.2

IMPLIKACIJE PRIMJENE STANDARDNIH KORELACIJSKIH STATISTIČKIH POSTUPAKA NA NORMATIVNIM I IPSATIZIRANIM REZULTATIMA MJERENJA EMOCIJA

Dina Šverko

Odsjek za psihologiju, Filozofski fakultet Sveučilišta u Zagrebu

Ivana Lučića 3, 10000 Zagreb

dsverko@ffzg.hr

Sažetak

Upotrebom upitnika i ček-lista za mjerenje emocionalnog doživljavanja možemo zahvatiti faktore koji nisu povezani sa specifičnim sadržajem pripadajućih čestica ili s atributima koji su predmet mjerenja korištenog instrumenta. To su faktori koji se odnose na različite vrste iskrivljavanja odgovora (npr. davanje ekstremnih odgovora) koji unose dodatnu pogrešku u rezultate mjerenja. Jedan od načina otklanjanja takvog nepoželjnog varijabiliteta je transformacija normativnih rezultata u ipsativne tzv. postupkom ipsatizacije. Smatra se da su standardni korelacijski statistički postupci neadekvatni za analizu ipsatiziranih rezultata zbog specifičnih psihometrijskih svojstava koja takvi rezultati pokazuju. Recentniji nalazi upućuju na suprotno, sugerirajući da su ipsativni rezultati ekvivalentni supstituti za normativne. Cilj je ovog rada dati prilog razjašnjavanju opisane nesuglasice u literaturi. U tu je svrhu, na 415 studenata Sveučilišta u Zagrebu, primijenjena mjera pozitivnog i negativnog afekta. Rezultati mjerenja izraženi su u normativnom i ipsativnom obliku. Komponentna faktorska analiza provedena je posebno na normativnim i posebno na ipsatiziranim podacima. Ishodi provedenih analiza su uspoređeni. Na kraju, raspravljene su prednosti i ograničenja ipsatiziranih u odnosu na normativne rezultate.

Glavne riječi: normativni i ipsativni rezultati, ipsatizacija, korelacijski postupci, faktorska analiza, emocije

UVOD

Rezultati mjerenja različitih psihologijskih fenomena i psiholoških atributa uglavnom se izražavaju brojčano kako bi se mogli jednostavnije uspoređivati, interpretirati te koristiti u različitim statističkim procedurama. Takvi kvantitativni pokazatelji ishoda psihologijskih mjerenja mogu biti izraženi u obliku sljedećih osnovnih jedinica mjerenja (Cattell, 1944):

a) *Bruto rezultat* je izravna brojčana informacija o uratku ispitanika. Svaki psihološki atribut neke osobe može se prikazati jedinstvenom distribucijom njegovih

bruto rezultata dobivenih primjenom određenog mjernog instrumenta. Takva distribucija ima svoj raspon, aritmetičku sredinu te druge statističke parametre koji su u interpretacijskom smislu izolirani od rezultata mjerenja ostalih atributa te iste osobe i od rezultata mjerenja istih atributa kod drugih osoba.

a) *Normativni rezultati* odražavaju oblik, aritmetičku sredinu i standardnu devijaciju zajedničke distribucije rezultata skupine ljudi. Normativni rezultat ovisi o rezultatima ostalih pojedinaca s kojima se uspoređuje pa je stoga moguće odrediti relativni položaj rezultata svakog pojedinca u odnosu na ostale, kao i veličinu razlike između rezultata različitih pojedinaca.

b) *Ipsativni rezultat* za razliku od normativnog omogućuje intraindividualnu u odnosu na interindividualnu usporedbu. To je rezultat koji sadrži informaciju o izmjenom atributu neke osobe u usporedbi s rezultatima ostalih izmjerenih atributa iste osobe pa se može odrediti relativni položaj rezultata mjerenja određenog atributa osobe u odnosu na ukupni prosječni uradak te osobe. Dakle, ipsativni rezultati mjerenja različitih atributa mogu se uspoređivati samo unutar rezultata pojedinca i ne daju nam nikakvu informaciju o relativnim ili apsolutnim razlikama između različitih pojedinaca.

Ipsativne rezultate možemo dobiti upotrebom ipsativnog mjernog instrumenta ili postupkom ipsatizacije rezultata.

Ipsativni mjerni instrument automatski proizvodi ipsativne rezultate jer je ipsativnost ugrađena u njega jer uključuje podjednako atraktivne/poželjne čestice prisilnog izbora ili prisilnog rangiranja, a svaki izbor ide na uštrb ostalih mogućih izbora (npr. Inventar stilova učenja, Kolb, 1999).

Ipsatizacija predstavlja transformaciju bruto rezultata ili normativnih rezultata u ipsativne. Takva transformacija se realizira na temelju jednostavnih matematičkih procedura. Aditivni ili devijacijski ipsatizirani rezultati se dobivaju kada se ukupna prosječna vrijednost rezultata na svim skalama za određenog pojedinca oduzme od normativnih rezultata tog pojedinca na pojedinim skalama. Takvi se ipsatizirani rezultati daljnjim postupcima mogu i standardizirati. Ovisno o korištenim matematičkim procedurama dobivaju se drugačije vrste ipsatiziranih rezultata kao što su multiplikativni ipsatizirani rezultati, ordinalni ipsatizirani rezultati i sl. (više u: Chan, 2003).

Clemans (1966) je predložio opću matematičku definiciju ipsativnih rezultata. Skupina varijabli $x = (x_1, \dots, x_k)$ je ipsativna kada je suma ili aritmetička sredina rezultata na tim varijablama konstanta za svakog pojedinca (matematički izraz 1). Takvo izjednačavanje aritmetičkih sredina različitih pojedinaca odgovara tzv. djelomičnoj ipsatizaciji, dok potpuna ipsatizacija uključuje i dodatno izjednačavanje varijanci.

$$X = [x_{ij}, i=1, \dots, n; j=1, \dots, k]; \quad \sum_{j=1}^k X_j = m \quad ; \quad i = 1, \dots, n \quad (1)$$

Iz ovoga slijedi da je svaki pojedini rezultat u potpunosti određen ostalim rezultatima istog pojedinca. Zbog te zavisnosti među rezultatima, ipsativni podaci imaju neka specifična statistička svojstva (Chan i Bentler, 1993, Clemans, 1966, Hicks, 1970, Radcliffe, 1963):

1. Suma varijanci i kovarijanci iznosi nula u svakom redu i stupcu ipsatizirane matrice varijanci i kovarijanci, što reducira rang te matrice za jedan. Stoga je ipsatizirana matrica varijanci i kovarijanci singularna i nema regularnog inverza.

2. Suma stupaca ili redova ipsativne korelacijske matrice mora iznositi nula, pod uvjetom da su varijance jednake.

3. Ako vrijedi prethodna tvrdnja, aritmetička sredina interkorelacija ipsatiziranih varijabli približavat će se vrijednosti $-1/(k-1)$, pri čemu je k broj varijabli, iako su originalne varijable ortogonalne.

4. Ukoliko je varijabla (x_i) uvijek pozitivna, barem jedan od preostalih $(k-1)$ elemenata u i retku i i stupcu ipsatizirane matrice varijanci i kovarijanci mora biti negativan. Takva negativna pristranost u kovarijancama će se pojaviti u svakom i retku i i stupcu ipsatizirane matrice varijanci i kovarijanci, bez obzira na inherentnu povezanost varijabli. Tako će ipsativni rezultati biti međusobno povezani čak iako su bruto rezultati nezavisni (Dunlap i Cornwell, 1994).

Iako se problem singularnosti matrice varijanci i kovarijanci može riješiti izbacivanjem jedne varijable, problem pristranih negativnih korelacija se ne može izbjeći. Takvo postojanje zavisnosti među ipsativnim rezultatima nije poželjno jer krši jedno od osnovnih pravila klasične teorije testova, nezavisnost varijance pogreške, što potom ima implikacije za statističku analizu takvih podataka.

Usprkos spomenutim ograničenjima ipsativnih rezultata, istraživači ih i dalje često koriste. Osnovna prednost ipsativnog skaliranja rezultata je redukcija pristranosti koja proizlazi iz načina odgovaranja (npr. Baron, 1996; Cheung i Chan, 2002; Saville i Willson, 1991).

U velikom broju upitnika ili inventara, koji se koriste u psihologijskim ispitivanjima različitih psihičkih fenomena ili atributa, traži se od osobe koja ih ispunjava da svoje odgovore na postavljena pitanja ili svoje slaganje s ponuđenim tvrdnjama izrazi na skali Likertova tipa od određenog broja stupnjeva. Različite osobe različito shvaćaju i koriste te skale. Zato rezultat izražen na skali Likertova tipa može biti predmet pristranosti u odgovaranju, koja proizlazi iz stila odgovaranja pojedinca koji ispunjava mjerni instrument.

Razlike među pojedincima u načinu ili stilu odgovaranja mogu biti i rezultat razlika u njihovim karakteristikama ličnosti. Neki pojedinci zbog svojeg sklopa karakteristika ličnosti precjenjuju, a drugi podcjenjuju svoje odgovore na skali Likertova tipa. Stoga, zaokružuju ekstremno visoke ili ekstremno niske vrijednosti skale pa pristranost može utjecati na individualna mjerenja na aditivni ili multiplikativni način.

Naravno da razlike u načinu odgovaranja mogu biti i rezultat odabrane strategije samoprezentacije kao što je npr. izražavanje socijalno poželjnih kvaliteta.

Prema Paulhusu (1991) pristranost u odgovaranju predstavlja sustavnu tendenciju odgovaranja pojedinca na čestice nekog mjernog instrumenta koja se ne temelji na specifičnom sadržaju čestice. Prema tome, pristranost u odgovaranju predstavlja izvor svojevrsnog "šuma" u rezultatima mjerenja određenog atributa. To je oblik sustavne pogreške koja varira među različitim pojedincima, ali ne varira među rezultatima istog ispitanika. Pokazalo se da ipsativno skaliranje rezultata može izdvojiti variranje koje proizlazi iz specifičnog sustavnog odgovaranja pojedinca od onog koji je povezan sa sadržajem čestice i zahvaća mjereni atribut.

Pristranosti u odgovaranju se mogu podijeliti u dvije osnovne kategorije (Paulhus, 1991):

1. stil odgovaranja, tendencija iskrivljavanja odgovora u određenom smjeru koja je više-manje nezavisna od sadržaja podražajne čestice, npr. sustavno davanje visokih procjena bez obzira na to jesu li podražajne čestice formulirane u pozitivnom ili negativnom smjeru;

2. udešenost kod odgovaranja, svjesna ili nesvjesna tendencija iskrivljavanja odgovora kako bi se proizvela određena slika o sebi, npr. davanje visokih procjena na podražajnim česticama koje su socijalno poželjnog sadržaja i niskih procjena na onima koje su socijalno nepoželjnog sadržaja.

Upotreba ipsativnih mjernih instrumenata i primjena postupka ipsatizacije rezultata predstavljaju neke od načina otklanjanja spomenutih vrsta sustavnih pogrešaka u rezultatima.

Iako postoje sličnosti među ipsativnim podacima dobivenim na ova dva načina, to su zapravo dva različita tipa ipsativnih podataka. Sličnost je u tome što zbroj svih rezultata odgovara konstanti, ali je zapravo to dobiveno primjenom različitih postupaka.

Zbog nepoželjnih statističkih svojstava ipsativnih rezultata, u literaturi nailazimo na oprečna mišljenja o primjeni standardnih statističkih tehnika na takvim podacima. To se posebno odnosi na primjenu standardnih metoda analize podataka koje se temelje na korelacijama kao što je, primjerice, faktorska analiza.

Clemans (1966) tvrdi da je provedba faktorske analize na ipsativnim podacima neutemeljena jer se ipsatizacijom, zapravo, otklanja osnovni izvor interindividualnog varijabiliteta u podacima.

Ten Berge (1999) je na podacima prikupljenim pomoću Rosenbergova upitnika samopoštovanja pokazao da se postupkom ipsatizacije iz podataka otklanja onaj dio varijabiliteta koji se inače može parcijalizirati ekstrakcijom "prosječne" komponente ili prvog centrioda. Uz to, primjećujemo da matrica korelacija ipsatiziranih varijabli podsjeća na matricu rezidualnih varijanci i kovarijaci nakon parcijalizacije prvog centrioda. Ako "prosječna" komponenta odražava spuriozne razlike među pojedincima koje proizlaze iz njihove pristranosti u odgovaranju, tada bi prva komponenta dobivena na normativnim podacima korespondirala drugoj komponenti dobivenoj na ipsatiziranim podacima, zatim bi druga komponenta dobivena na normativnim

podacima korespondirala trećoj komponenti dobivenoj na ipsatiziranim podacima i tako dalje redom. To pravilo vrijedi samo u slučaju kada su varijable čestice upitnika formiranog od uravnoteženog, odnosno podjednakog broja pozitivno i negativno formuliranih čestica.

Brojna istraživanja su došla do zaključka da faktorska analiza na ipsativnim podacima rezultira ekstrakcijom bipolarnih faktora, koji su artefakt pristranih negativnih korelacija među ipsativnim rezultatima te ne reflektiraju stvarnu faktorsku strukturu u populaciji (npr. Baron, 1996, Bartram, 1996, Chan, 2003, Closs, 1996, Cornwell i Dunlap, 1994, Dunlap i Cornwell, 1994, Guilford, 1952, Johnson, Wood i Blinkhorn, 1988).

Međutim, u literaturi nailazimo na recentna istraživanja na temelju čijih nalaza se zaključuje da faktorska analiza ipsativnih podataka može dati interpretabilne rezultate (npr. Geiger, Boyle i Pinto, 1993, Loo, 1996, 1999, Pickworth i Schoeman, 2000, Saville i Willson, 1991, Willcoxson i Prosser, 1996, Yahya, 1998).

U ovom radu pokušavamo razjasniti koja je grupa autora u pravu u debati oko teorijskih i empirijskih implikacija korištenja faktorske analize na ipsativnim podacima. Točnije, cilj ovoga rada je utvrditi komparabilnost interpretacija strukture emocija koje proizlaze iz rezultata faktorskih analiza provedenih na dvije različite vrste podataka, normativnim i ipsativnim.

METODA

Sudionici

U istraživanju je sudjelovalo 415 studenata (od čega 57% studentica) s tri različita fakulteta na Zagrebačkom sveučilištu: Filozofskog (studenti psihologije), Kineziološkog i Edukacijsko-rehabilitacijskog fakulteta. U dobi od 18 do 23 godine bilo je 96% uzorka, a prosječna dob sudionika bila je 20 godina ($SD = 1,47$).

Mjerni instrumenti

Skala pozitivnih i negativnih emocija (Šverko, 2006) mjeri trenutačno emocionalno stanje. Sastoji se od 83 riječi koje se odnose na emocije i koje formiraju ukupno 28 emocionalnih subskala (privrženost, prijateljstvo, radost, smirenost, ljubav, strast, znatiželja, oduševljenje, uzbuđenje, suosjećanje, skrušenost, ljubomora, krivnja, sram, ljutnja, neprijateljstvo, jeza, strah, povrijeđenost, usamljenost, tuga, patnja, jad, dosada, neizvjesnost, napetost, tjeskoba, prezir). Od ispitanika se traži da procijene stupanj u kojem trenutačno doživljavaju svaku pojedinu emociju na skali Likertova tipa od četiri stupnja (1 - uopće se tako ne osjećam; 4 - u potpunosti se tako osjećam). Cronbach alpha koeficijenti unutarnje konzistencije za 26 od

28 subskala su zadovoljavajući za istraživačke svrhe i kreću se od 0,60 (subskala dosade) do 0,86 (subskala radosti). Dvije subskale (dosada i skrušenost) od kojih svaka uključuje samo dvije čestice imaju pouzdanost nižu od 0,60 ($\alpha_{\text{dosada}} = 0,41$; $\alpha_{\text{skrušenost}} = 0,39$).

Postupak

Ispitivanje je provedeno grupno u predavaonicama tijekom obavezne nastave. Nakon što su saslušali opću uputu, sudionici su dobili upitnik i počeli s ispunjavanjem. Ispitivanje je bilo anonimno i trajalo je oko 15 minuta.

Normativni rezultati ispitanika na pojedinim emocionalnim subskalama formirani su kao aditivne linearne kombinacije varijabli određenih emocionalnih stanja, a zatim pretvoreni u z-vrijednosti.

Ipsatizirani rezultati dobiveni su transformacijom normativnih skalnih rezultata u ipsativne postupkom *ipsatizacije*. Za svakog se ispitanika izračunala aritmetička sredina njegovih rezultata na 28 emocionalnih subskala te je zatim ta aritmetička sredina oduzeta od ukupnog rezultata na pojedinoj subskali za tog ispitanika.

REZULTATI I RASPRAVA

Najprije su izračunate interkorelacije između 28 emocionalnih subskala, posebno za normativne i posebno za ipsatizirane rezultate.¹

Opažen je značajno veći broj negativnih povezanosti između ipsatiziranih subskala u odnosu na normativne. Od ukupnog broja interkorelacija (r_{ij}) među ipsatiziranim subskalama, njih 43% je statistički značajno i negativnog predznaka. Kod normativnih rezultata, samo 13% sveukupnih različitih interkorelacija među subskalama je statistički značajno i ujedno u negativnom smjeru. Možemo reći da među ipsatiziranim subskalama postoji negativna multikolinearnost koja nije opažena među normativnim subskalama. Clemans (1966) je demonstrirao da broj negativnih vrijednosti u korelacijskoj matrici izračunatoj na ipsativnim podacima ovisi o broju uključenih varijabli i distribuciji korelacija među tim varijablama izračunatim na normativnim podacima. Otprilike polovina ipsativnih interkorelacija će uvijek biti negativna s tendencijom porasta negativnih interkorelacija što je broj varijabli/atributa manji i što se distribucija normativnih interkorelacija više razlikuje od normalne.

Prosječna interkorelacija među ipsatiziranim subskalama iznosi -0,02, što je u skladu s jednim od obilježja matrice korelacije ipsatiziranih rezultata prema kojem

1 Matricu interkorelacija 28 emocionalnih subskala izračunatih na normativnim i ipsatiziranim rezultatima moguće je dobiti na zahtjev od autora.

je prosječna povezanost među ipsatiziranim varijablama negativna ili bliska nuli. Takav obrazac povezanosti je zapravo analitički predvidljiv.

Suprotno tome, prosječna interkorelacija među subskalama izračunata na temelju normativnih rezultata iznosi 0,26. Za ovu korelaciju možemo reći da je primarno uvjetovana povezanošću sadržaja emocionalnih subskala kao i psihološkim karakteristikama ispitanika, a nije posljedica matematičke transformacije skala kao što je to slučaj kod ipsatiziranih rezultata. Međutim, postoji mogućnost da je ova korelacija umjetno povećana zbog pristranosti u odgovaranju te da je korelacija među konstruktima odmjerenih normativnim skalama realno manja.

Transformacijom normativnih rezultata u ipsativne, velik broj interkorelacija među subskalama promijenio je predznak. Usprkos tome postoji visoko podudaranje između ukupnih rezultata na emocionalnim subskalama izraženih u normativnom i ipsativnom obliku. Prosječna korelacija između normativnih i ipsatiziranih rezultata na odgovarajućim emocionalnim subskalama iznosi 0,79. Analizom korelacija između normativnih i ipsatiziranih rezultata na pojedinim subskalama (tablica 1) primjećujemo da najniže slaganje postoji za subskalnu neprijateljstva ($r = 0,31$), a najviše za subskale strasti i napetosti ($r = 0,95$).

Nismo očekivali potpunu korelaciju između normativnih i ipsativnih skalnih rezultata iako su ipsativni rezultati nastali transformacijom normativnih. Naime, transformacija o kojoj je riječ nije linearnog karaktera i predstavlja promjenu u metrici. Normativni rezultat svakog pojedinca umanjuje se za različitu vrijednost, tj. njegov prosječan rezultat.

Tablica 1. Povezanost između ipsatiziranih i normativnih skalnih rezultata

	r		r
Privrženost	0,81	Neprijateljstvo	0,31
Prijateljstvo	0,94	Jeza	0,58
Radost	0,94	Strah	0,93
Smirenost	0,92	Povrijeđenost	0,58
Ljubav	0,92	Usamljenost	0,89
Strast	0,95	Tuga	0,54
Znatiželja	0,77	Patnja	0,55
Oduševljenje	0,91	Jad	0,91
Uzbuđenje	0,89	Dosada	0,83
Suosjećanje	0,85	Neizvjesnost	0,91
Skrušenost	0,59	Napetost	0,95
Ljubomora	0,82	Tjeskoba	0,94
Krivnja	0,68	Prezir	0,85
Sram	0,43	\bar{r}	0,79
Ljutnja	0,89		

Napomena: za sve koeficijente korelacije vrijedi $p < 0,01$

Iako povezanost između ipsatiziranih i normativnih skalnih rezultata nije jednaka jedinici, ona je i dalje visoka. Na temelju toga, mogli bismo reći da ova dva tipa različito formiranih rezultata dovode do sličnih zaključaka kada ih koristimo u statističkim analizama. Međutim, to bi bilo netočno jer obrazac interkorelacija među emocionalnim skalama izračunatim na ipsatiziranim rezultatima i obrazac povezanosti između emocionalnih skala izračunatim na normativnim rezultatima nisu usporedivi i dovode do sasvim različitih interpretacija povezanosti emocionalnih subskala. Tako, na primjer, na temelju korelacija normativnih rezultata zaključili bismo da su subskale neprijateljstva i strasti u umjereno visokoj negativnoj povezanosti ($r = -0,46$), ali korelacija među tim istim subskalama izračunata na ipsatiziranim podacima iznosi $+0,18$ te bismo je opisali kao postojanje niske i pozitivne povezanosti između emocija neprijateljstva i strasti.

Kako bismo odgovorili na osnovni problem ovog istraživanja, proveli smo dvije komponentne faktorske analize, jedna na normativnim a druga na ipsatiziranim podacima.

Prema Keiser-Guttmanovu kriteriju od 28 estrahiranih komponenti na temelju korelacija između normativnih skalnih rezultata, značajne su samo četiri. Vrijednosti karakterističnih korijena za prve četiri estrahirane komponente iznose redom: 10,39; 4,76; 1,51 i 1,11. Vrijednosti karakterističnih korijena su najveće za prve dvije komponente, koje pridonose najvećem objašnjenju ukupne analizirane varijance u usporedbi s ostalim estrahiranim komponentama. Inspekcijom *scree-plota* koji stavlja u odnos broj estrahiranih komponenti i njihove korespondentne vrijednosti karakterističnih korijena također se može zaključiti da se dvije komponente izdvajaju kao značajne.

Isto tako, dvije komponente se izdvajaju kao značajne i kod faktorizacije matrice korelacije ipsatiziranih rezultata. Karakteristični korijeni za prvih 7 estrahiranih komponenti iznose redom: 7,58; 3,95; 1,73; 1,40; 1,23; 1,21 i 1,05. Vrijednost karakterističnog korijena 28., odnosno posljednje estrahirane komponente iznosi nula, što je posljedica reduciranog ranga korelacijske matrice ipsatiziranih podataka.

Prve dvije komponente estrahirane na temelju povezanosti između ipsatiziranih podataka imaju najveće karakteristične korijene te objašnjavaju najvišu proporciju ukupne varijance, dok ostale komponente pojedinačno skromno pridonose objašnjavanju varijance analiziranih varijabli.

U skladu s navedenim komponentne faktorske analize provedene su još jednom uz ograničenje na ekstrakciju samo dva faktora i uz varimax rotaciju. Provedena analiza na normativnim rezultatima pokazuje jasnu, jednostavnu i interpretabilnu strukturu, u kojoj negativne emocije definiraju prvi faktor, a pozitivne drugi faktor (tablica 2). Ovakva faktorska struktura emocija, koja pretpostavlja postojanje dimenzije pozitivnog afekta i dimenzije negativnog afekta, potvrđena je i u drugim sličnim istraživanjima u različitim kulturama (npr. Knez i Hygge, 2001, Watson i Tellegen, 1985, Yik i Russell, 2003, Yik, Russell i Feldman Barrett, 1999).

Tablica 2. Rezultati faktorskih analiza s varimax rotacijom

	Normativni rezultati		Ipsatizirani rezultati		Ipsatizirani rezultati - Interpretabilno faktorsko rješenje
	Faktor 1	Faktor 2	Faktor 1	Faktor 2	Faktor 1
Jad	0,84		0,73		0,76
Ljutnja	0,83		0,56		0,57
Napetost	0,83		0,81		0,62
Tjeskoba	0,82		0,83		0,67
Tuga	0,81			0,63	0,58
Strah	0,79		0,66		0,45
Usamljenost	0,78		0,63	0,33	0,71
Povrijeđenost	0,76			0,47	0,42
Sram	0,74		0,62		0,36
Prezir	0,70		0,32		0,39
Patnja	0,69			0,64	0,42
Neizvjesnost	0,69		0,56		0,39
Skrušenost	0,69			0,52	0,37
Krivnja	0,67			0,37	0,36
Jeza	0,66			0,61	0,36
Neprijateljstvo	0,64			0,76	< 0,3
Ljubomora	0,58		< 0,3	< 0,3	< 0,3
Suosjećanje	0,52		< 0,3	< 0,3	< 0,3
Smirenost	-0,44		-0,78		-0,54
Uzbuđenje		0,80	-0,47	-0,56	-0,69
Oduševljenje		0,80	-0,67	-0,36	-0,76
Prijateljstvo		0,77	-0,50	-0,49	-0,69
Radost	-0,42	0,72	-0,81		-0,81
Ljubav		0,68	-0,51	-0,38	-0,64
Značajelja		0,65	-0,48		-0,50
Privrženost		0,62	-0,43		-0,51
Strast	0,42	0,55		-0,60	< 0,3
Dosada		-0,41		0,66	< 0,3
% objašnjene varijance	54		41		27

Faktorska struktura dobivena na ipsatiziranim podacima nije tako jasna i interpretabilna. Naime, iako su se dva faktora izdvojila kao značajna na temelju spomenutih kriterija, oba se ne mogu psihološki smisleno interpretirati. Kao i u dosadašnjim istraživanjima ipsativna faktorska solucija proizvela je bipolarne faktore (npr. Alwin i Krosnick, 1985, Baron, 1996, Chan, 2003, Closs, 1996, Cornwell i Dunlap, 1994, Dunlap i Cornwell, 1994). Glavna kritika upućena faktorizaciji ipsativnih podataka odnosi se na smislenost otkrivanja latentnih faktora u podlozi analitički odredivih interkorelacija varijabli.

Ako usporedimo faktorske strukture dobivene na normativnim podacima, i one na ipsatiziranim podacima, uočavamo da nema velike sličnosti. Prvi faktor dobiven na normativnim podacima u interpretacijskom smislu nije slična ni prvom ni drugom faktoru estrahiranom na ipsatiziranim podacima.

Izgleda da je faktorska struktura dobivena na ipsatiziranim podacima artefakt postupka ipsatizacije podataka a ne rezultat latentne strukture koja se nalazi u podlozi povezanosti među emocionalnim varijablama.

U skladu s tim, Tucker (1956) tvrdi da nema smisla provoditi faktorsku analizu na ipsativnim podacima, jer to može služiti samo utvrđivanju ranga matrice.

Možemo zaključiti da faktorsko rješenje dobiveno na normativnim podacima daje veći prilog utvrđivanju strukture afekata, u usporedbi s rezultatima faktorske analize dobivenim na ipsatiziranim podacima, koji se djelomično mogu objasniti negativnom multikolineranošću koja je inherentna ipsativnim podacima.

Kako bi se usporedila dvofaktorska rješenja dobivena na ipsativnim i normativnim podacima izračunati su faktorski bodovi za svakog ispitanika na prvom i drugom ekstrahiranom faktoru i to u oba slučaja, na ipsatiziranim i normativnim podacima. Zatim su izračunati koeficijenti korelacije između faktorskih bodova korespondentnih faktora dobivenim na ipsativnim i normativnim podacima (tablica 3).

Postoji visoka povezanost između 1. faktora dobivenog na ipsatiziranim rezultatima i onog dobivenog na normativnim rezultatima. Isto tako, utvrđena je gotovo identična veličina koeficijenta povezanosti između 2. faktora dobivenog na ipsatiziranim rezultatima i onog dobivenog na normativnim podacima.

Dobivena relativno visoka povezanost između prve dvije komponente estrahirane na dvije vrste različito formiranih rezultata mogla se očekivati zbog velikog broja nisko do umjereno visoko povezanih emocionalnih subskala uključenih u analizu. Naime, istraživanja su pokazala da ako uspoređujemo faktorske strukture dobivene na ipsativnim i normativnim rezultatima, najveća vjerojatnost da se dobiju usporedive strukture postoji kada imamo veći broj skala i ako su, na razini normativnih podataka, interkorelacije među njima niske (Baron, 1996, Bartram, 1996, Saville i Willson, 1991).

Tablica 3. Povezanost između faktorskih bodova na faktorima estrahiranim na temelju normativnih i ipsatiziranih rezultata

		Ipsatizirani rezultati	
		1. faktor	2. faktor
Normativni rezultati	1. faktor	0,86**	-
	2. faktor	-	-0,85**

** $p < 0,01$

Usprkos tom visokom stupnju sličnosti faktora dobivenih ovim analizama, usporedbom koeficijenata korelacije između emocionalnih subskala i estrahiranih faktora u matricama faktorske strukture uočavamo da su to zapravo dva vrlo različita faktorska rješenja u interpretacijskom smislu. S obzirom na to, ne možemo se složiti sa stajalištem Savillea i Willsona (1991) prema kojem ova dva različita načina skaliranja rezultata dovode do sličnih ishoda.

Kada ne bismo imali normativne rezultate, zaključak o strukturi afekta samo na temelju ipsativnih podataka ne bi se poklapao s dvodimenzionalnim modelom. Čini se da je jednodimenzionalno faktorsko rješenje jedino interpretabilno rješenje u slučaju naših ipsativnih podataka. Takvo faktorsko rješenje, prikazano u tablici 2, govori u prilog postojanju generalne bipolarne dimenzije afekta duž koje su raspoređene emocije, od onih pozitivnog hedonističkog tona (na jednom polu) do onih negativnog hedonističkog tona (na drugom polu).

ZAKLJUČAK

Na prvi se pogled čini da su normativno i ipsativno skalirani rezultati prilično slični budući da su korelacije 28 emocionalnih subskala dobivenih na normativnim i ipsativnim podacima relativno visoke.

Međutim, ipsativni rezultati na emocionalnim skalama međusobno ne koreliraju kao što koreliraju te iste skale izražene kao normativni rezultati. Korelacije izračunate na ipsativnim podacima ne odražavaju ni veličinu ni smjer onih dobivenih na normativnim podacima. Dakle, interpretacije koje bismo dobili iz matrice korelacija emocionalnih subskala izračunatih na ipsativnim i onoj izračunatoj na normativnim podacima sasvim su različite.

Također, faktori estrahirani faktorizacijom korelacijske matrice ipsativnih podataka i oni dobiveni na normativnim podacima pokazuju visoko slaganje. Međutim, inspekcijom matrice faktorske strukture dobivene na ipsatiziranim podacima i one dobivene na normativnim podacima vidimo da su one različite i da dovode do različitih interpretacija i zaključaka o prirodi strukture afekata. Stoga, nalazi ovog istraživanja upućuju na to da ipsatizirane rezultate ne možemo koristiti kao supstitute za normativne u statističkim postupcima koji se temelje na korelacijama.

Hicks (1970), a onda i 30-ak godina kasnije Chan (2003) strogo zaključuju da se upotreba ipsatiziranih rezultata može opravdati samo u slučaju kada su prikupljeni podaci "kontaminirani" sustavnom pogreškom koja proizlazi iz pristranog načina odgovaranja i koja smanjuje njihovu valjanost, a uz to smo sigurni da će ipsatizacija reducirati pristranost u podacima i time povećati njihovu valjanost u većoj mjeri nego što bi se to postiglo drugim neipsativnim postupcima kontrole pristranosti.

Budući da ipsativni rezultati pružaju informaciju o intraindividualnom poretku skalnih rezultata pojedinca, oni u suštini predstavljaju ordinalnu razinu mjerenja pa su standardne parametrijske analize, uključujući one temeljene na Paersono-

vim koeficijentima korelacije, neadekvatne za njihovu analizu (Baronu, 1996). Zato Cornwell i Dunlap (1994) predlažu multinomialne tehnike za analizu ipsativnih podataka. Ipsativni podaci su se pokazali adekvatnima za tipološka istraživanja koja koriste različite metode klasteriranja i ostale analize Q-tipa (npr. Borgen i Barnett, 1987).

Recentnija istraživanja bave se razvojem novih metoda u okviru modela konfirmatorne faktorske analize koje omogućavaju interindividualne usporedbe na temelju analize ipsativnih podataka. Te se analize temelje na reprodukciji normativne strukture iz ipsativnih rezultata (Chan, 2003, Chan i Bentler, 1993, Cheung i Chan, 2002).

Na kraju, možemo zaključiti da ipsativni podaci mogu biti korisni, posebno za intraindividualne usporedbe i u situacijama kada smo sigurni da su prikupljeni podaci iskrivljeni zbog pristranosti u odgovaranju, ali uz primjenu statističkih procedura koje su sukladne informacijama sadržanim u takvim podacima.

LITERATURA

- Alwin, D.F., Krosnick, J.A. (1985). The measurement of values in surveys: A comparison of ratings and rankings. *Public Opinion Survey*, 49, 535-552.
- Baron, H. (1996). Strengths and limitations of ipsative measurement. *Journal of Occupational and Organizational Psychology*, 69, 49-56.
- Bartram, D. (1996). The relationship between ipsatized and normative measures of personality. *Journal of Occupational and Organizational Psychology*, 69, 25-39.
- Borgen, F.H., Barnett, D.C. (1987). Applying cluster analysis in counseling psychology research. *Journal of Counseling Psychology*, 34, 456-468.
- Cattell, R.B. (1944). Psychological measurement: Normative, ipsative, interactive. *Psychological Review*, 51, 292-303.
- Chan, W. (2003). Analyzing ipsative data in psychological research. *Behaviormetrika*, 30, 99-121.
- Chan, W., Bentler, P.M. (1993). The covariance structure analysis of ipsative data. *Sociological Methods & Research*, 2, 214-247.
- Cheung, M.W.L., Chan, W. (2002). Reducing uniform response bias with ipsative measurement in multiple-group confirmatory factor analysis. *Structural Equation Modeling*, 9, 55-77.
- Clemans, W.V. (1966). An analytic and empirical examination of some properties of ipsative measures. *Psychometric Monographs*, 14, 1-56.
- Closs, S.L. (1996). On the factoring and interpretation of ipsative data. *Journal of Occupational and Organizational Psychology*, 69, 41-47.
- Cornwell, J.M., Dunlap, W.P. (1994). On the questionable soundness of factoring ipsative data: A response to Saville & Willson. *Journal of Occupational and Organizational Psychology*, 67, 89-100.

- Dunlap, W.P, Cornwell, J.M. (1994). Factor analysis of ipsative measures. *Multivariate Behavioral Research*, 29, 115-126.
- Geiger, M.A., Boyle, E.J., Pinto, J. (1993). A factor analysis of Kolb's revised learning style inventory. *Educational and Psychological Measurement*, 52, 753-759.
- Guilford, J.P. (1952). When not to factor analyze. *Psychological Bulletin*, 49, 26-37.
- Hicks, L.E. (1970). Some properties of ipsative, normative, and forced-choice normative measures. *Psychological Bulletin*, 74, 167-184.
- Johnson, C.E., Wood, R., Blinkhorn, S.F. (1988). Spuriousness and spuriousness: The use of ipsative personality tests. *Journal of Occupational Psychology*, 61, 153-162.
- Knez, I., Hygge, S. (2001). The circumplex structure of affect: A Swedish version. *Scandinavian Journal of Psychology*, 42, 389-398.
- Kolb, D.A. (1999). *Learning style inventory*, version 3. Boston: The Hay Group.
- Loo, R. (1996). Construct validity and classification stability of the revised learning style inventory (LSI-1985). *Educational and Psychological Measurement*, 56, 529-536.
- Loo, R. (1999). Issues in factor-analyzing ipsative measures: The learning style inventory (LSI-1985) example. *Journal of Business and Psychology*, 14, 149-154.
- Paulhus, D.L. (1991). Measures of personality and social psychological attitudes. U: J.P. Robinson, R.P. Shaver, (Ur.), *Measures of social psychological attitudes series*, 17-59. San Diego: Academic.
- Pickworth, G.E., Schoeman, W.J. (2000). The psychometric properties of the Learning Style Inventory and the Learning Style Questionnaire: Two normative measures of learning styles. *South African Journal of Psychology*, 30, 44-52.
- Radcliffe, J.A. (1963). Some properties of ipsative score matrices and their relevance for some current interest tests. *Australian Journal of Psychology*, 15, 1-11.
- Saville, P., Willson, E. (1991). The reliability and validity of normative and ipsative approaches in the measurement of personality. *Journal of Occupational Psychology*, 64, 219-238.
- Šverko, D. (2006). *Insight to the structure of emotion*. Neobjavljena doktorska disertacija. Fakultet za psihologiju Sveučilišta u Trstu (Italija).
- Ten Berge, J.M.F. (1999). A legitimate case of component analysis of ipsative measures, and partialling the mean as an alternative to ipsatization. *Multivariate Behavioral Research*, 34, 89-102.
- Tucker, L. R. (1956). *Factor Analysis of Double Centered Score Matrices*. Research Memorandum 56-6. Princeton: Educational Testing Service.
- Watson, D., Tellegen, A. (1985). Toward a consensual structure of mood. *Psychological Bulletin*, 98, 219-235.
- Willcoxson, L., Prosser, M. (1996). Kolb's learning style inventory (1985). Review and further study of validity and reliability. *British Journal of Educational Psychology*, 66, 247-257.
- Yahya, I. (1998). Willcoxson and Prosser's factor analyses on Kolb's (1985) LSI data: reflections and re-analyses. *British Journal of Educational Psychology*, 68, 281-286.
- Yik, M.S.M., Russell, J.A. (2003). Chinese affect circumplex: I. Structure of recalled momentary affect. *Asian Journal of Social Psychology*, 6, 185-200.

Yik, M.S.M., Russell, J.A., Feldman Barrett, L. (1999). Structure of self-reported current affect: Integration and beyond. *Journal of Personality and Social Psychology*, 77, 600-619.

IMPLICATIONS OF THE APPLICATION OF STANDARD CORRELATIONAL PROCEDURES ON NORMATIVE AND IPSATIZED SCORES IN EMOTION RESEARCH

Summary

The assessment of emotional experience through inventories and check-lists can be influenced by factors that are not related to specific items' content or to the attributes the used instrument is designed to measure. Such factors are different forms of response distortions (e.g. extreme response style) that can "contaminate" the gathered data. One way to eliminate such undesired sources of variation is the transformation of normative into ipsative data by ipsatization. It was argued that standard correlational statistical procedures are inappropriate for the analysis of ipsatized data due of their specific psychometric properties. More recently published papers concluded the opposite, that ipsative scores are equivalent substitutes for normative scores. The aim of this study was to clarify this issue by comparing the results of factor analyses performed on normative and ipsative data. For this purpose, a positive and negative affect measure was administered to 415 psychology students at the University of Zagreb. The benefits and limitations of ipsative versus normative data are discussed.

Key words: normative and ipsative scores, ipsatization, correlational procedures, factor analysis, emotion

Primljeno: 08. 07. 2009.